

I.Ü.Siyasal Bilgiler Fakültesi Dergisi
No: 25 (Ekim 2001)

YAPAY SINIR AGLARI

Ögr. Gör.Dr. Melda AKIN*

Abstract

In this paper, artificial neural networks which is a new computational paradigm which can be also be considered as a new statistical modeling and estimation tool, is described. Artificial neural networks have been successfully applied to the problems where there is a nonlinear mapping between the inputs and the outputs such as pattern recognition, control and time series modeling, etc. First, the history then the artificial neuron models is explained. Then, the multiplayer perceptron type artificial neural network and the learning algorithm, i.e., error backpropagation algorithm are given.

1. GIRIS

Son zamanlarda özellikle dogrusal olmayan gönderim problemleri ve modellemede yapay sinir aqlari (YSA) denetimden ekonometrik modellemeye kadar bir çok alanda basari ile kullanilmaya baslanmistir. Bu makalede arastiricilara bir baslangiç yapabilmeleri için temel bilgiler verilerek yapay sinir aqlari tanitilacaktır.

Yapay sinir aqlari bir hesaplama yöntemidir ve çıkis noktasi beynin davranislarinin modellenmesidir. YSA geleneksel bilgisayar sistemlerinde kullanilandan tamamen farkli bir bilgi isleme teknigidir. YSA'lar ayni zamanda bir çok veri isleyip sonuç üreterek çok zor ve baska yöntemlerle çözülmesi imkansiz problemleri çözebilirler. Genellikle, bilgisayarların güvenilirliđi ile insan uzmanliginin beklentilerini birleştirmek amaciyla kullanilirlar.

YSA'lar bu güne kadar basta örüntü tanıma (pattern recognition) ve denetim kurami ve zaman serisi modelleme olmak üzere çok sayıda alanda basarili bir sekilde uygulanmislardır. Bu bağlamda YSA'lar bir istatistiksel modelleme ve kestirim yordamlari sinifi olarak da gözönüne alınabilir. Bu tür uygulamalarda amaç, bir eğitim veri kümesine bağlı olarak bu verileri üreten istatistiksel süreci modellemek ve yeni verilerle en iyi kestirimi yapabilmektir. İstatistiksel modelleme problemleri üç gruba ayrilabilir: yogunluk kestirimi, siniflandırma ve regresyon. Bu nitelikleriyle YSA'lar sosyal bilimlerde de bir çok uygulama alanı bulmaktadır.

* İstanbul Üniversitesi, Siyasal Bilgiler Fakültesi, Öğretim Görevlisi.

Makalenin ikinci bölümünde YSA'ların kısaca tarihçesi verilmekte, üçüncü bölümde YSA modelleri, dördüncü bölümde bağlantılar, besinci bölümde öğrenme yöntemleri, altıncı bölümde ise en çok kullanılan YSA tipi olan çok katmanlı ağaçlar anlatılmaktadır. Yedinci bölümde ise sonuçlar verilmektedir

2. TARİHÇE

Modern yapay sinir ağları dönemi Mc Culloch ve Pitts'in (1943) öncü çalışmasıyla başlamıştır. Bu makalede nörofizyoloji ve matematiksel mantık konusundaki çalışmaları bir araya getiren yapay sinir ağı modeli ve ilgili kuram ortaya konmuştur. Bu çalışma hem yapay sinir ağları hem de yapay zeka disiplinlerini doğuran çalışma olarak kabul edilir.

YSA alanındaki bir sonraki önemli gelişme 1949'da Hebb'in kitabının yayınlanmasıyla oldu. İlk defa bu çalışmada sinaptik değişim için fizyolojik öğrenme kuralı verilmiştir.

'Beyin için Tasarım' isimli kitap 1952'de Ross Ashby tarafından yayınlanmıştır. Kitap canlılardaki sinir sisteminden etkilenerek yazılmıştır.

Rosenblatt (1958) ağaç (perceptron) adlı modeli ve daha sonra bu modelin eğitimiyle ilgili kurami geliştirince YSA'lar özellikle örüntü tanıma alanında uygulanır hale geldi ve uzun bir süre de her sorunun çözümünde kullanılabileceği varsayıldı. Minsky ve Papert(1969) bu modelin yeterli olmadığını gösterdiler. Bu da bu konuya ayrılan kaynakların hemen tamamen kesilmesine neden oldu, maddi yetersizlikler nedeniyle araştırmalar azaldı.

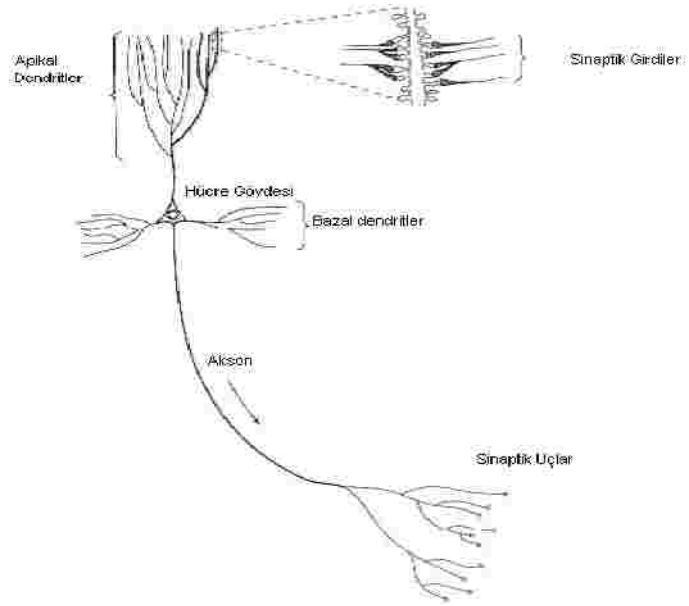
1982'de Hopfield'in bir araştırması yeni gelişmelere olanak tanımıştır. Modelin eksikliklerini gideren çok katmanlı ağaç(multi-layer perceptron) modeli ve hata geri yayma yordamı (error back propagation) farklı disiplinlerden birçok bilim adamının oluşturduğu bir grubun yayınladığı kitapla (Rumelhart ve McClelland, 1986) ortaya konmuş ve sürekli geliştirilerek bugün de başarıyla kullanılmaktadır.

3. YAPAY SINIR AĞLARI MODELLERİ

3.1. Nöronlar

YSA'nın ne olduğunu ve ne yapabildiğini anlamak için beyindeki nöronların (beyin hücreleri) incelenmesi gereklidir.


Sekil 1'de insan beyindeki tipik bir nöronun yapısı gösterilmektedir. Beynimiz farklı tipte yaklaşık olarak 10^{11} nörondan oluşmaktadır. Çalışması ise basit olarak şöyledir. Girdi sinyalleri dendritler yoluyla toplanır, üretilen çıktı akson yoluyla sinapslara gönderilir. Çıktı, girdi sinyallerinin toplamına bağlıdır. Toplam belli bir eşik değerinden daha büyükse nöron tetiklenir ve elektrik sinyalleri akson yoluyla sinaptik bağlantılara gider. Sinapslar diğer nöronların dendritlerine bağlıdır. Nöronlar binlerce bağlantı yardımı ile birbirlerine bağlı oldukları için bir ağ yapısı oluştururlar.



Sekil 1: Nöron (Haykin 1999)

3.2. Yapay Sinir Ağı İşlem Birimleri

Sekil 2'den görüldüğü gibi YSA işlem birimi de doğal nöronlara benzerlik gösterir. Bir işlem biriminin girdilerinin sayısı, diğer işlem birimlerinin sayısına ve bunların söz konusu işlem birimine olan bağlantılarına bağlıdır. Her girdinin bir ağırlığı vardır



Sekil 2: İdeal yapay nöron

YSA'daki bir işlem birimi şöyle çalışır.

Adım 1. İlk olarak ağdaki diğer işlem birimlerinden gönderilen toplam sinyal hesaplanır.

Adım 2. İçsel etkilenimin düzeyi etkilenim işlevi kullanılarak belirlenir.

Adım 3. Birim ağdaki diğer işlem birimlerine sinyal gönderilir, bu sinyalin birimin içsel etkileniminin bir işlevidir. Bir işlemciden diğerine sinyal gönderme işlemi ağırlıklı bağlantılar üzerinden yapılır.

3.3. Bağlantılar

Her bir YSA'da çok sayıda işlem birimi vardır. Değişik hesaplamalarda farklı ağ yapıları kullanılır. Genel olarak bağlantılarına göre YSA'lar iki sınıfa ayrılır: ileri-beslemeli ve geri-beslemeli ağ yapıları. İleri beslemeli yapıda bağlar tek yönlü olup çevrimler yoktur. Geri beslemeli bir yapıda ise bağlar her hangi bir topoloji oluşturacak şekilde seçilebilir. İleri beslemeli ağ yapılarında birimler genellikle katmanlar oluşturacak şekilde yerleştirilirler. Böyle bir yapıda her birim yalnızca kendinden sonraki katmandaki birimlere bağlanır, aynı katmandaki birimlere ya da daha önceki katmana bağlantı yoktur.


Ağ yapısında çevrimler olmazsa hesaplama düzgün olarak girdilerden çıktılarına doğru ilerlenerek yapılabilir. Bu durumda bir önceki zaman adımındaki etkilenim hesaplamada hiçbir rol oynamaz. Çünkü, daha önceki bir birime geri beslenmez. Dolayısıyla ileri beslemeli bir YSA'nın ağırlıkları dışında bir iç durumu yoktur. Sadece o anki girdilere ve ağırlıklara bağlı olarak çıktı hesaplanır.

Geri beslemeli bir yapıda ise önceki zaman adımlarındaki verilerde çıktıyı etkiler. Bu yüzden bu tür yapılar kararsız hale gelebilir ya da kaotik bir davranış gösterebilir. Dolayısıyla da bir veri girildiğinde kararlı bir çıktı elde etmek çok uzun süre alabilir ve öğrenme güçleşebilir. Ancak bellekli işlevler gibi daha karmaşık işlevler ileri beslemeli yapılardan daha çok geri beslemeli yapılar kullanılarak modellenilebilir.

3.4. Etkilenim işlevleri

Değişik YSA modellerinde değişik etkilenim işlevleri kullanılır. Şekil 3'de en çok kullanılan işlevler olan basamak, rampa ve sigmoid işlevleri gösterilmiştir.

Basamak işlevinin bir eğisi vardır. Esik, birimi tetikleme için gerekli olan en düşük ağırlıklı girdi toplamını gösterir. Girdi esikten büyük olduğu zaman çıktı 1 olur, aksi halde ise 0 olur. Biyolojik olarak 1 nöronun tetiklenmesi, 0 ise tetiklenmemesine karşılık gelir. Çoğunlukla esik yerine fazladan bir girdi ağırlığı kullanmak matematiksel işlemleri kolaylaştırır.



Sekil 3: Etkilenim islevleri. (a) Basamak islevi, (b) Rampa islevi, (c) Sigmoid islevi.


Sigmoid islevi ise süreklidir ve x 'nin degeri $-\infty$ to ∞ arasında degisirken islevin degeri 0'dan 1'e monotonik olarak artar. Sigmoidin kazanci β , geçis bölgesinin dikligini belirler. Kazanç sonsuza giderken sigmoid de esik islevine yaklasir. Sigmoidin avantajlarından birisi türevinin her noktada tanımlı olmasıdır. Bu özellik sayesinde çok katmanlı yapay sinir ağları için gradyan temelli bir öğrenme yordamı geliştirmek mümkün olmuştur.

3.5. Yapay Sinir Alarının Islev Yaklastirma Özelligi

YSA'ların önemi genel amaçlı bir doğrusal olmayan girdi-çikti gönderim aracı olarak kullanılabilmelerinden kaynaklanmaktadır. Evrensel Yaklaşım Teoremi (Hornik, Stinchcombe ve White, 1989) tek katmanlı bir ÇKA'nın verilen bir x_1, \dots, x_m girdi kümesi ile istenen çiktiya $f(x_1, \dots, x_m)$ düzgün bir ϵ yaklaşım hesaplamaya yeterli olacağını göstermektedir. Ancak teorem tek katmanın öğrenme süresi, uygulama kolaylığı ve genelleme açısından optimum olduğunu söylememektedir. Bu nedenle YSA'ların ağ yapısının (kaç saklı katman olacağı, her katmanda kaç birim olacağını) belirlenmesi zor bir problem olarak ortaya çıkmaktadır.

3.6. Çok Katmanlı Algaç Modeli

Bu bölümde en çok kullanılan YSA tipi olan çok katmanlı algaç (ÇKA) tanıtılacaktır. Algaç modelinde girdi n -boyutlu bir vektördür. Algaç yukarıda belirtildiği gibi girdi vektörünün bütün bileşenlerinin ağırlıklı bir toplamını hesaplar ve bu toplamdan bir esik degerini (q) çıkarır. Bu işlemin sonucu doğrusal olmayan bir etkilenim islevine girdi olarak beslenir (Sekil 4).



Sekil 4: Algaç

Hesaplamalarda kolaylık olması için esik değeri de bir ağırlık olarak alınır ($W_0 = \theta$). Bu ağırlık, değeri her zaman +1 olan bir ek girdinin ağırlığı olarak kullanılır. Ağırlıklı toplam bu şekilde genişletilmiş girdi vektörüyle ağırlık vektörününü iç çarpımı olarak ifade edilebilir. Algaç tarafında yapılan işlem aşağıda verilmiştir:

$$\begin{aligned} y &= \mathbf{w}^T \cdot \mathbf{x} \\ u &= f_A(y) \end{aligned} \quad (1)$$

Algaçlar katmanlar halinde arka arkaya yerleştirilince genellikle doğrusal olmayan işlev olarak sigmoid (lojistik) işlev kullanılır:

Çok katmanlı algaçta üç değişik tip katman bulunur:

- § Girdi Katmanı. Bu katman ağırlık dışındaki kaynaklardan girdileri alan birimlerden oluşur. Bu birimlerin özel bir aktarma işlevleri yoktur, girdilerini çıktılarına hiç değiştirmeden aktarırlar.
- § Saklı Katmanlar. Bir YSA'da bir veya daha çok saklı katman bulunabilir. Bu katmanlar girdi katmanı ile çıktı katmanı arasında yer alırlar. Girdi ya da çıktı katmanı değildirler.
- § Çıktı Katmanı. Bu katman dış ortama işaret gönderen birimlerden oluşur. Bu birimlerin çıktıları aynı zamanda ağırlık çıktıları da oluşturur.

Girdi vektörü birinci katman algaçlarına beslenir, bu katmanın çıktıları bir sonraki katmanın birimlerine girdi oluşturur, v.b. Genellikle l . katmanın bütün birimleri $l+1$. katmandaki bütün birimlere bağlıdır. Çok katmanlı algaçlar saklı katman sayılarına göre sınıflandırılırlar.

Son katmanda birden fazla çıktı birimi olması genellikle örüntü tanıma uygulamalarında raslanan bir durumdur. Bu tür uygulamalarda çıktı birimleri sınıflara karşılık gelir.

4. ÖĞRENME YÖNTEMLERİ

YSA'ların mimarilerinin belirlenmesi ve bağlantı ağırlıklarının hesaplanması için öğrenme yöntemleri adı verilen ve yapay zekada örneklerden öğrenme yöntemi olarak tanımlanan tümevarımsal yöntemler kullanılır (Russell ve Norvig 1995). Bu yöntemlerde öğrenmesi beklenen dizgeye öğrenilecek kavramla ilgili örnekler gösterilir ve dizgenin bir genellemeye giderek istenen bir kavramı oluşturması beklenir. Örneklerden öğrenme üç şekilde yapılabilir.

- Gözetmenli Öğrenme: Bu öğrenme yönteminde verilen bir girdi için istenen çıktı değeri bir gözetmen tarafından dizgeye bildirilir. Degisik örnekler verilerek, dizgenin çıktisiyla istenen çıktı arasındaki farkı belirli bir ölçüte göre en aza indirmesi beklenir.
- Kuvvetlendirmeli Öğrenme: Bir dizi ardisik girdiye karsilik çıktı ürettikten sonra dizgeye basarili basarisiz seklinde nitel bir bilgi verilir. Bu bilgiyi kullanarak dizgenin basarimini yükseltmesi beklenir. Bu yöntem gözetmenli öğrenmenin özel bir durumudur.
- Gözetmensiz Öğrenme: Burada bir gözetmen bulunmayip yapay sinir aginin, girdilerin içindeki ilişkileri ve düzenlilikleri bulması beklenir.

YSA'larda her üç yöntemde kullanılmakta ise de uygulamalarda en çok gözetmenli öğrenme yöntemi kullanilir. Asagida çok katmanli algaçlar için anlatilacak olan öğrenme yöntemi buna tipik bir örnektir.

4.1. Çok Katmanli Algaçlar İçin Öğrenme Yöntemleri

YSA'larda gözetmenli öğrenmede en sik raslanan yaklasim bir gradyan azalimi (gradient descent) yordami kullanilmasidir. Bir ÇKA'nin öğrenme asamasinin klasik kosulsuz, dogrusal olmayan bir optimizasyon problemi olarak ele alinabilecegi gösterilmistir (Topçuoglu ve Akin 1994). Bu tür bir problemin çözümü tipik olarak bir amaç islevini en büyükmek ya da en küçükmek için bir küme bagimsiz degiskeni yinelemeli olarak degistirmek sekindedir. ÇKA bu modele gayet uygundur: agirliklar bagimsiz degiskenler olarak ve eğitim kümesi üstündeki hatalarin karelerinin toplami da amaç islevi olarak alinabilir. Hata ölçütü ya da amaç islevi asagidaki gibi tanimlanir:

$$E(w) = \frac{1}{2} \sum_{im} (V_i^m - O_i^m)^2 = \frac{1}{2} \sum_{im} (V_i^m - \sum_k w_{ik} e_k^m)^2 \quad (2)$$

Burada O_i^m ÇKA'nin çıktisi, V_i^m her i ve m için istenen çıktı. e_k^m m . örüntü için girdiyi göstermektedir.

Agi egitmenin amaci, agirliklari, sonuçta her örüntü için agin çıktisinin istenen çıktıya esit olacağı sekilde degistirmektir. Bir çok optimizasyon yöntemi olmasına karsin her birinin hareket noktaları baskadir (Murray 1979), (Fletcher 1991). Bazi yöntemler yalnızca en küçüklenecek islevin hesaplanmasını gerektirirken digerleri bu islevin bagimsiz degiskenlere göre kısmi türevlerinin de hesaplanmasını gerektirmektedir. Çok Katmanli Algaç durumunda gradyan denklem (2)'deki $E(w)$ 'nin agirliklara göre kısmi türevlerinden olusur. Eğitimde kullanilabilecek dogrusal olmayan optimizasyon yöntemleri asagidaki gibi siralanabilir:

§ Gradyan Azalması (Gradient Descent) yöntemi

§ Eslenik Gradyanlar (Conjugate Gradients) yöntemi

§ Newtonumsu (Quasi Newton) yöntemler

§ Levenberg-Marquardt yöntemi

Bazi yöntemler bilgisayarla hesaplamada N^2 mertebesinde yer gerektirirken diğerleri N mertebesinde yer gerektirir. Burada N boyut (ağırlık) sayısıdır. N 'in küçük değerleri için aradaki fark pratik açıdan önemli değilken bazı problemler için gereken bellek miktarı çok büyüyebilir.

Genel bir işlevin bir aşak(extremum) noktası yerel ya da global olabilir. Doğrusal sistemlerin dışında herhangi bir doğrusal olmayan problemin global aşak noktasının bulunması çok zor bir problemdir.

Yerel minimumu hesaplamak için sık kullanılan bir yöntem, bir çok rasgele başlangıç noktasından başlamak ve çok boyutlu uzaydaki bir yüzey boyunca bir ilerleme kuralına göre bir aşak noktasına ulaşana kadar ilerlemektir. Bu yöntemlerde, bulunan aşak noktalarının en uçtakinin seçilmesiyle optimizasyon probleminin çözümünün bulunacağı varsayılır. Bu stratejinin ana fikri, $t+1$ anındaki yeni vektör olan x^{t+1} 'in t anındaki vektör olan x^t cinsinden yinelemeli olarak aşağıdaki şekilde hesaplanabilmesidir:

$$x^{t+1} = x^t - k.B.g \quad (3)$$

burada g , x^t 'de hesaplanan gradyandır B gradyanın bir dönüşüm matrisi olup bir arama yönü gösterir ve k da adım boyudur. Bütün optimizasyon yöntemleri k ve B 'yi seçmek için değişik yöntemler önerir. Gradyanın bileşenleri

$$g_j = \frac{\nabla E(x)}{\nabla x_j} \quad (4)$$

şeklinde ifade edilebilir.

4.2. Gradyan Azalması Yordamı

Gradyan azalması yordamı, rasgele bir başlangıç noktasından başlayarak her girdi örüntüsü için YSA'nin tam istenen çıktıyı üretmesini sağlayacak bir ağırlık kümesinin ardışık iyileştirmelerle bulunmasını sağlayan bir yöntemdir.

Hata ölçütü $E(w)$ (2) denklemindeki şekilde verilince, bir ağırlık kümesi w_{ik} 'yi w uzayında tanımladığı yüzeyden yokus aşağıya ilerlenerek iyileştirilebilir. Gradyan azalması yordamı her w_{ik} 'yi E 'nin mevcut konumdaki gradyanıyla orantılı bir Dw_{ik} miktarı kadar değiştirme prensibine dayanır:

$$\begin{aligned}\Delta w_{ik} &= -h \frac{\partial E}{\partial w_{ik}} \\ &= h \sum_m (V_i^m - O_i^m) e_k^m\end{aligned}\quad (5)$$

Bu denklemi (3) denklemiyle karşılaştırırsak burada $k=h$ ve $B=1$ olduğu görülür. Eger ağırlıklarda (5) denklemiyle verilen değişiklikleri her bir girdi örüntüsü e_k^m için sırayla yaparsak m . örüntü için gerekli değişiklik aşağıdaki gibi hesaplanabilir:

$$\Delta w_{ik} = h(V_i^m - O_i^m)e_k^m \quad (6)$$


Eger hataları (ya da delta'ları) $d_i^m = V_i^m - O_i^m$ şeklinde tanımlarsak,

$$\Delta w_{ik} = h d_i^m e_k^m \quad (7)$$

elde edilir. Bu denklemlerdeki sonuca genellikle Delta Kuralı, kuralı adı verilir.

4.3. Hata Geri Yayma Yordamı

Hata geri yayma yordamı gradyan aramaya dayanan ve bir amaç işlevini en küçükleyecek ağırlıklarını bulmaya yarayan ve programlaması ve anlaşılması daha kolay olduğu için en sık kullanılan yordamdır. Şekil 5'de denklemlerde kullanılacak semboller gösterilmektedir.



Şekil 5: Çok katmanlı ağaç.

Amaç islevini veren denklem (2) asagidaki sekilde yeniden yazilabilir:

$$E(w) = \sum_{p=1}^{N_p} E_p(w) \quad (8)$$

Burada N_p eğitim örüntüsü sayisini, $E_p(w)$ ise p . örüntü için hatalarin karesinin toplamini göstermektedir. $E_p(w)$ asagidaki sekilde yazilabilir:

$$E_p(w) = \frac{1}{2} \sum_{q=1}^{N_q} (d_q^p - \Phi_q^p)^2 \quad (9)$$

Burada N_q çıktı katmanındaki birim sayisini, d_q^p q . birimin p . örüntü için istenen çıktisini, Φ_q^p ise q . birimin p . örüntü için gerçek çıktisini göstermektedir. Yukaridaki iki denklem birlestirilerek

$$E(w) = \frac{1}{2} \sum_{p=1}^{N_p} \sum_{q=1}^{N_q} (d_q^p - \Phi_q^p)^2 \quad (10)$$

yazilabilir. Burada ,

$$\Phi_q^p = \Phi_q^p(u_q^p) \quad (11)$$

çikti islevi olup yukarida belirtildiği gibi genellikle sigmoid olarak kullanilir.

Yordamda kullanılacak bütün kısmi türevler zincir kurali kullanılarak hesaplanabilir. Hata geri yayma yordaminda ağırlıkların yinelenmeli olarak asagidaki sekilde belirlenir:

$$w_{mn}(t+1) = w_{mn}(t) - \eta \frac{\partial E(w)}{\partial w_{mn}} \Big|_{w(t)} \quad (12)$$

$$w_{mn}(t+1) = w_{mn}(t) - \eta \sum_{p=1}^{N_p} \frac{\partial E_p(w)}{\partial w_{mn}} \Big|_{w(t)}$$

Burada η öğrenme hızı adı verilen pozitif bir parametredir. E_p 'nin ağırlıklara göre kısmi türevlerini yerine koyarsak her ağırlıkta yapılması gereken değişiklik için asagidaki ifadeyi buluruz:

$$\Delta w_{pq} = \eta \sum_{\text{örüntü}} d_{\text{çikti}} V_{\text{girdi}} \quad (13)$$

Burada girdi ve çıktı ilgili bağlantının iki uç noktası p ve q 'ye aittir ve V ilgili birimin girdisindeki etkilenimi göstermektedir. δ 'nin anlamı ilgili katmana bağlıdır. Burada

katsayılar ileri yöndeki ağırlıklar olan w_{ij} 'lerdir, ancak bu durumda isareti ileri doğru yaymak yerine hatayı geriye doğru yaymaktadırlar. Bu yüzden bu yönteme hata geri yayma yöntemi adı verilir.

Bir ÇKA'yi hata geri yayma yordamı kullanarak eğitime iki şekilde yapılabilir: yerel güncelleme yöntemi ve birikimli güncelleme yöntemi.

- § Yerel Güncelleme Yöntemi. Bu yöntemde her örüntü n , girdiden ağıza beslenince hatalar hemen hesaplanır ve ağırlıklar değiştirilir. Bu şekilde her adımda hata islevi azalır (yeterince küçük h için) ve ardışık adımların yerel gradyana uyması sağlanır.
- § Birikimli Güncelleme Yöntemi. Bu yöntemde ise ağırlıklar bütün örüntüler ağıza beslendikten sonra güncellenir.

Sekil 6'da Hata Geri Yayma Yordamı verilmektedir. Bu yordamda ağıdaki her ağırlık için öğrenme parametresi aynı alınmıştır. Bazı araştırmacılar öğrenme parametrelerini her katman için farklı hatta her ağırlık için farklı seçmektedirler. Genellikle en iyi öğrenme parametresini belirlemek zordur ve deneme yanılma yöntemi kullanılır.

Adım 1. Ağırlıklara küçük rassal ilk değerler ata..

Adım 2. Bir örüntü seç ve girdi katmanına besle.

Adım 3. Isareti ağı boyunca aşağıdaki denklemi kullanarak her i ve m için ağı çıktılarını hesaplanıncaya kadar ileriye yay.

$$V_i^m = g\left(\sum_j w_{ij}^m V_j^{m-1}\right) \quad (14)$$

Burada, V_i^m m . katmandaki i .birimin çıktısını w_{ij}^m ise V_j^{m-1} ile V_i^m arasındaki bağlantının ağırlığını göstermektedir. m hesaplanan yapıldığı katmandır.

Adım 4. Çıktı katmanının deltalarını hesapla.

Adım 5. Önceki katmanların deltalarını hataları geri yayarak hesapla.

Adım 6. Denklem (13)'ü kullanarak bütün bağlantıları aşağıdaki şekilde güncelle.

$$w_{ij}^{\text{yeni}} = w_{ij}^{\text{eski}} + \Delta w_{ij} \quad (15)$$

Adım 7. Adım 2'ye git ve bir sonraki örüntü için işlemi tekrarla.

Sekil 6: Hata geri yayma yordamı.

Gradyan azalması, η küçükse öğrenme işlemi çok yavaş ilerler. η 'nin çok büyük olduğu durumlarda da ağırlıkların değerlerinde büyük salınımlar görülür. Bu sorunun üstesinden gelmek için kullanılan yöntemlerden biri bir momentum terimi eklemektir.

Buradaki düşünce her bağlantıya bir eylemsizlik ya da momentum vermektir. Bu şekilde ağırlıkların değerlerinin her güncellemede büyük salınımlar yapması yerine ortalama yokus aşağı "kuvvet" doğrultusunda değişime eğilimi göstermesi beklenir.

Bu düzeltme her ağırlık değişimine bir önceki adımdaki değişiklikten bir katkı ekleyerek yapılabilir:

$$\Delta w_{pq}(t+1) = -\eta \frac{\partial E_p}{\partial w_{pq}} + \alpha \Delta w_{pq}(t) \quad (16)$$

Momentum parametresi (α) 0 ile 1 arasında olmalıdır. Uygulamada genellikle 0.9 değeri seçilir.

Yordamın durması için kullanılacak bir kaç ölçüt vardır.

- § Gradyanın bir minimum değer altına düşmesi. Burada gradyanın büyüklüğünü temel olarak alınır. Yordam gradyanın büyüklüğü yeterince küçükse durdurulabilir, çünkü tanım gereği minimumda gradyan sıfır olacaktır.
- § Hatanın bir minimum değer altına düşmesi. İkinci olarak $E(w)$ 'nin belli bir değerin altına düşmesi halinde yordam durdurulabilir.
- § Yineleme sayısı limitine ulaşılması. Üçüncü olarak da belli sayıda yineleme yapıldıktan sonra işleme son verilebilir. Bu durumda yordamın minimuma ulaşma garantisi yoktur.
- § Çapraz Geçerleme. Dördüncü yöntem ise çapraz geçerleme (cross validation) yöntemidir. Veri, ağırlık eğitiminde kullanılan bir eğitim kümesi ve ağırlık genelleme başarımını ölçmede kullanılan bir deneme kümesi olarak iki kümeye ayrılır. Öğrenme sırasında ağırlık eğitim kümesindeki başarımı sürekli artmaya devam etmesine karşın deney kümesindeki başarımı bir noktaya kadar arttıktan sonra azalmaya başlar. Bu noktada ağırlık eğitim kümesini ezberlemeye başlamış demektir ve eğitim kümesinde bulunmayan örüntüler için genelleme yeteneğini yitirir. Bu yüzden eğitim bu noktada durdurulmalıdır. İlk üç ölçüt parametrelerin seçimine çok hassastır ve iyi bir seçim yapılmazsa sonuçlar çok kötü olabilir. Çapraz geçerleme bu seçimden etkilenmez.

5. SONUÇ

Bu makalede çeşitli istatistiksel uygulamalarda kullanılacak yeni bir hesaplama yöntemi olan yapay sinir ağları tanıtılmıştır. Özellikle borsalarda zaman serilerinin modellenmesinde ve genel olarak yeterli veri bulunan her çeşit doğrusal olmayan regresyon uygulamalarında çok başarılı sonuçlar veren YSA'ların sosyal bilimlerin alanında da kullanımının hızla artması beklenmektedir.

KAYNAKLAR

- Ashby, W. R., 1952. Design for a Brain, New York:Wiley.
- Fletcher R., 1991. Practical Methods of Optimisation, John-Wiley & Sons, London.
- Haykin, S. 1999. Neural Networks: A Comprehensive Foundation, İkinci Baskı, Upper Saddle River, NJ: Prentice-Hall.
- Hebb, D.O., 1949. The Organization of Behavior:A Neurophysiological Theory, New York:Wiley.
- Hopfield, J.J, 1982. “Neural networks and physical systems with emergent collective computational abilities,” Proceedings of the National Academy of Sciences, USA, vol. 79, pp.2554-2558.
- Hornik K., M. Stinchcombe ve H. White, 1989. “Multi-Layer Feedforward Networks Are Universal Approximators,” Neural Networks, Cilt. 2, pp.35-366.
- McCullogh, W.S. ve W. Pitts, 1943. “A logical calculus of the ideas immanent in nervous activity,” Bulletin of the Mathematical Biophysics, vol. 5, pp.115-133.
- Minsky, M.L. ve S. A. Papert, 1969. Perceptrons, Cambridge, MA: MIT Press.
- Murray, W., 1979. Numerical Methods for Unconstrained Optimisation, Academic Press, London.
- Rosenblatt, F., 1958. “The Perceptron: A probabilistic model for information storage and organization in the brain,” Psychological Review, vol. 65, pp.386-408.
- Rumelhart, D.E. ve J.L McClelland, ed., 1986. Parallel and Distributed Computing: Explorations in the Microstructure of Cognition, vol.1-2, Cambridge:MA:MIT Press.
- Russell, S.J., ve P. Norvig, 1995. Artificial Intelligence: A Modern Approach, Upper Saddle River, NJ: Prentice-Hall.
- Topçuoglu, H. ve H. L. Akin, 1994., “Comparison of Learning Algorithms,” 3. Yapay Zeka ve Yapay Sinir Ağıları Sempozyumu.